



## PROCESAMIENTO DE IMÁGENES PARA LA IDENTIFICACIÓN DE UVA Y FOLLAJE USANDO TÉCNICAS DE CLASIFICACIÓN NO SUPERVISADAS

Correa, Christian;

Tutores: Valero, Constantino; Barreiro, Pilar

Departamento de Ing. Rural. E.T.S.I.A. Universidad Politécnica de Madrid  
c.correaf@alumnos.upm.es

### RESUMEN

Diversas investigaciones han intentado resolver el problema de identificación de frutos u hojas mediante imágenes digitales, pero sólo lo han logrado parcialmente. Por esto, el objetivo de este trabajo es explorar una metodología de identificación que permita estimar áreas de hojas y racimos en viñedos, empleando imágenes en el espectro visible (RGB) y en el infrarrojo cercano (RGIR). El problema de la identificación fue abordando por dos vías, forma y color. En el caso de la identificación por forma se empleó la transformada circular de Hough y en el de la identificación por color se emplearon las técnicas de clasificación no supervisada denominadas *k-means* y *Fuzzy c-means*. Se determinó que la clasificación mediante *k-means* sobre el espacio  $L^*a^*b^*$ , para imágenes RGB y sobre el índice SAVI en las imágenes RGIR, son las técnicas más adecuadas. En cuanto a la identificación por forma, ésta resultó aplicable sólo en condiciones muy particulares.

**Palabras clave:** *k-means*, *fuzzy c-means*, SAVI.

### INTRODUCCIÓN

Dotar de visión a una máquina no resulta complejo, ni costoso debido a la masificación de las cámaras digitales y de los ordenadores. Sin embargo, el hacer que dicha máquina tenga la capacidad de identificar lo que está viendo, resulta más complejo de lo que aparenta.

Se han desarrollado diversas técnicas de identificación orientadas principalmente a resolver problemas del ámbito industrial, como por ejemplo, control de calidad en el tamaño o volumen de piezas mecánicas, o ya en el ámbito agrícola, identificación de defectos y tamaño de diversos productos hortofrutícolas (Bjurström *et al.* 2002, Fernández *et al.* 2008, Berenstein *et al.* 2010). Dichas técnicas se basan principalmente en la identificación por el color y la forma del producto en cuestión.

La mayor parte de las aplicaciones de estas técnicas se realizan bajo condiciones controladas (ambiente estructurado) de iluminación, velocidad y distancia al producto, lo que hace que los algoritmos empleados sean válidos sólo bajo esas condiciones. Así, las técnicas clásicas no son aplicables en ambientes no estructurados (Tian *et al.* 1998), por lo que en los últimos años se ha comenzado a emplear técnicas provenientes del área de la inteligencia artificial que permiten un mayor grado de generalización de los entornos y objetos a identificar (Ming *et al.* 2006).

Las técnicas de clasificación por color las podemos separar en supervisadas y no supervisadas. Las supervisadas son aquellas en donde le señalamos al algoritmo, cuantas clases tendremos y cómo será el prototipo de dicha clase. En las no supervisadas, es el propio algoritmo el que decide que características han de cumplir los elementos que pertenecerán a una determinada clase.

Dado que en los entornos no estructurados las condiciones son variables, establecer *a priori* que características tendrán los elementos de una clase conduce a un sesgo, lo que limita las posibles soluciones. Esto es debido a que las características que se impongan resultarán válidas sólo para situaciones particulares (Kotsiantis, 2007).

Debido a esto, las técnicas de clasificación no supervisada resultan de interés para la clasificación en entornos no estructurados, ya que agrupan datos (píxeles en el caso de



las imágenes) sin un criterio preestablecido, sólo minimizan la distancia entre píxeles dentro de cada grupo. Restando luego, sólo identificar qué datos han sido agrupados en cada clase.

Nos hemos propuesto emplear técnicas de clasificación no supervisadas para la identificación de uvas y hojas en viñedos mediante imágenes en los espectros visible e infrarrojo.

## MATERIAL Y MÉTODOS

### Espacios de color

Disponíamos de un conjunto de imágenes de un viñedo (200) tomadas tanto en el rango visible RGB, (Red, Green, Blue) como en el infrarrojo cercano RGIR (Red, Green, Infrared).

Como primera etapa en el procesamiento de las imágenes RGB, estas fueron transformadas a los espacios de color HSV, HSI, CMYK,  $L^*a^*b^*$ , XYZ y Ohta, (Ohta *et al.*, 1980) para determinar así, cuál de ellos o su combinación es el más adecuado para el proceso de identificación de hojas, racimos, sarmientos y fondo. Esto bajo las premisas de que píxeles de un mismo color pertenecen al mismo tipo de objetos y de que algunos espacios de color diferencian mejor los objetos que otros.

### Índices espectrales

Por otra parte las imágenes RGIR fueron transformadas a imágenes en las que cada pixel representa un índice espectral. Los índices empleados fueron: el Índice de Vegetación de Diferencia Normalizada NDVI y el Índice de Vegetación Ajustado al Suelo (SAVI) (Chuvieco *et al.*, 2002). Ya que estos índices permiten separar vegetación del fondo o suelo.

### Clasificación e Identificación

El problema de la identificación fue abordando por dos vías, forma y color. En el caso de la identificación por forma se empleó la transformada circular de Hough, como la describe Fernández *et al.* 2008 y en el caso de la identificación por color se emplearon las técnicas de clasificación no supervisada denominadas *k-means* y *Fuzzy c-means* descritas por Ray *et al.*, 1999 y Chuang *et al.*, 2006. Las que básicamente agrupan píxeles de colores similares, en un número preestablecido de grupos.

### Color

**K-means Cluster.** El algoritmo de K-means está basado en el análisis de las varianzas. Agrupa un conjunto de datos en un número predefinido de clases o grupos. Comienza con un conjunto aleatorio de centroides de cada una de las clases y continúa reasignando los datos del conjunto de píxeles a los distintos centroides, basándose en minimizar la distancia entre los píxeles y el centroide. El proceso de reasignación no se detiene hasta que se converge al criterio de parada (se alcanzó un número fijo de iteraciones o los centroides no cambian). Las distancias empleadas fueron Minkowski, Euclidia, Manhattan y del Coseno.

**Fuzzy c-means.** Este algoritmo de clasificación es una variante del algoritmo k-means cluster. La diferencia entre ambos es que en K-means cada elemento pertenece a un único grupo, mientras que fuzzy c-means permite la pertenencia parcial de un dato a más de un grupo. Otra diferencia radica en la forma en la que se actualizan los centroides.

### Forma

**Transformada circular de Hough.** La transformada de Hough comienza obteniendo el mapa de bordes de la imagen, la información obtenida se utiliza para deducir la ubicación de los centros (x, y) y los valores de los radios (r), por último se lleva a cabo la detección de máximos. La desventaja de este método es la alta demanda de recursos



computacionales, ya que debe realizar múltiples operaciones en forma recursiva y almacenar los resultados parciales de dichas operaciones (Fernández *et al.*, 2008.).

Estas técnicas fueron aplicadas sobre un conjunto de 200 imágenes RGB de 350x500 y otras 200 RGIR de la misma resolución. Luego procesadas en rutinas desarrolladas en Matlab 7.5, en un ordenador con procesador Pentium 4 ® de 1.6 MHz y 1Gb de RAM.

### RESULTADOS Y DISCUSIÓN


De los espacios de color empleados los que mejores resultados muestran son el  $L^*a^*b^*$  en particular los canales  $a^*$   $b^*$  (magenta-verde y amarillo-azul) y el CMYK, en específico el canal Y (amarillo). Ya que dichos canales permiten separar de mejor modo vegetación, uvas, sarmientos y fondo.

Merecen especial atención los canales L (luminosidad) y K (negro) de los espacios antes mencionados, ya que estos guardan relación con el nivel de intensidad lumínica de los píxeles, lo que resulta útil a la hora de separar o unir conjuntos de píxeles de igual color pero distinta intensidad.

En cuanto a los índices de vegetación NDVI y SAVI, el que mejores resultados entregó fue SAVI, ya que permite eliminar el fondo de las imágenes y conservar sólo la vegetación. Luego SAVI permite crear dos grupos, vegetación y no vegetación.


En lo que se refiere a los algoritmos de clasificación, aplicados sobre imágenes en el espectro visible, K-means usando ocho clases en el espacio  $L^*a^*b^*$  es capaz de separar adecuadamente las uvas del resto de los componentes de la imagen, así como las hojas (secas y verdes). De las distancias usadas para evaluar K-means, la que mejor desempeño mostró fue la denominada del coseno, ya que las otras tienden a incluir el fondo en la clase que contiene a la uva.

En cuanto a Fuzzy c-means, esta técnica de clasificación mostró mejores resultados que los de k-means, como se puede apreciar en la Figura 1c y 1d, en donde incluso identifica racimos difíciles de visualizar en la imagen original. Sin embargo, requiere 55 segundos para clasificar una imagen, en comparación con los 9 segundos de K-means.



a) Imagen original en el espacio de color RGB

b) Identificación por k-means, clase 2.



c) Clasificación por k-means, ocho clases.

d) Clasificación por Fuzzy c-means, ocho clases.



**Figura 1. Resultados obtenidos con los diversos métodos de clasificación.**  
**Encerrado en los círculos se observan zonas mal clasificadas por Fuzzy c-means.**

Con respecto a la clasificación por forma, la transformada de Hough no mostro resultados que puedan ser empleados para la identificación, debido a que la frontera de cada una de las bayas, es difusa debido a su color y a la sombra que proyecta sobre sus vecinas.

## CONCLUSIONES

Si bien es cierto que los resultados mostrados por fuzzy c-means resultan prometedores, esta técnica no puede ser aplicada en tiempo real (menos de 60ms) por la limitación del tiempo de procesado, por lo que la técnica de k-means resultaría más adecuada para dicho objetivo.

Ambas técnicas mostraron una excelente capacidad de generalización al ser aplicadas a imágenes con diversos grados de iluminación. Pero ambas técnicas presentan la desventaja de no ser consistentes en el tiempo, esto es, al aplicar la clasificación a una misma imagen, las etiquetas que le asigna a cada grupo son distintas, por lo que se debe trabajar en desarrollo de algoritmos que garanticen consistencia, o que caractericen cada grupo.

En cuanto a las imágenes IR, estas separan muy bien uvas del resto y en particular del fondo o porosidad, al emplear un umbral adecuado para SAVI. Sin embargo, se debe emplear alguna técnica de clasificación, como k-means, para distinguir entre hojas verdes secas y sarmientos.

De ser factible, se deberían emplear cuatro bandas para una clasificación robusta del color o de los índices de vegetación. Esto es, RGB convertido a  $L^*a^*b$  junto con el canal IR de las imágenes RGIR.

## BIBLIOGRAFÍA

- Berenstein R., had B. Shahrar, Amir Shapiro, and Yael Edan. 2010. Grape clusters and foliage detection algorithms for autonomous selective vineyard sprayer. *Intell. Serv. Robot.* 3, 4, pages 233-243.
- Bjurström, Håkan and Jon Svensson. 2002 Assessment of Grapevine Vigour Using Image Processing, Master Thesis, Linköping University, Sweden.
- Chuang K., H. Tzeng, S. Chen, J. Wu, T. Chen. 2006. Fuzzy c-means clustering with spatial information for image segmentation, *Computerized Medical Imaging and Graphics*, Pages 9-15.
- Chuvieco, E., Martín, M.P. y Palacios, A. 2002. "Assessment of different spectral indices in the red-near-infrared spectral domain for burned land discrimination" *Int. J. of Remote Sensing*, vol. 23, pp. 5103-5110.
- Fernández Leandro A.F., Manuel M. Oliveira. 2008. Real-time line detection through an improved Hough transform voting scheme. *Pattern Recognition*, Volume 41, Issue 1, Pages 299-314.
- Kotsiantis, S. B. 2007. Supervised Machine Learning: A Review of Classification Techniques. *Informatics*, 31, 249-268.
- Tian L., David C. Slaughter. 1998. Environmentally adaptive segmentation algorithm for outdoor image segmentation, *Computers and Electronics in Agriculture*, Volume 21, Pages 153-168.
- Ming Gao; Tien-Fu Lu; 2006. "Image Processing and Analysis for Autonomous Grapevine Pruning," *Mechatronics and Automation, Proceedings of the 2006 IEEE International Conference*, vol., no., pp.922-927.
- Ohta Yu-Ichi, Tokeo Kamode. 1980. Color information for region segmentation. [J]. *Computer Graphics and Image Processing* 13. Pages 222-241.
- Ray S. and R H Turi: 1999. Determination of number of clusters in K-means clustering and application in color image segmentation, *Proceedings of ICAPRDT'99*, pp 137-143.